

# **ANÁLISIS COMPARATIVO DE TÉCNICAS DE VISIÓN POR COMPUTADOR PARA LA CLASIFICACIÓN DE SUBSUELOS DE PEREIRA-RISARALDA**

**JAIME PELAEZ DELGADO**

Proyecto de grado presentado como requisito parcial  
para aspirar al título de Ingeniero Electrónico

Director

M.Sc. (C) Arley Bejarano Martínez

**UNIVERSIDAD TECNOLÓGICA DE PEREIRA**  
**PROGRAMA DE INGENIERÍA ELECTRÓNICA**  
**PEREIRA**  
**2018**

<b>Tabla de contenido</b>	<b>Pag.</b>
<b>1. INTRODUCCIÓN.....</b>	<b>6</b>
1.1 PLANTEAMIENTO DEL PROBLEMA .....	7
1.2 JUSTIFICACIÓN .....	8
1.3 OBJETIVO GENERAL.....	9
1.4 OBJETIVOS ESPECÍFICOS .....	9
1.5 ESTADO DEL ARTE .....	10
<b>2. MARCO TEÓRICO .....</b>	<b>12</b>
2.1 Base de datos .....	12
2.2 Algoritmo .....	12
2.3 Espacios de color .....	13
2.4 Modelo de color RGB .....	13
2.5 Modelo de color CIE L*A*B* .....	15
2.6 Modelo de color HSV .....	17
2.7 Transformada de Fourier .....	19
2.8 Máquina de soporte vectorial .....	19
2.9 Estadística .....	20
2.10 Matriz de confusión .....	21
<b>3. METODOLOGÍA .....</b>	<b>23</b>
<b>4. ANÁLISIS Y RESULTADOS .....</b>	<b>32</b>
<b>5. CONCLUSIONES .....</b>	<b>44</b>
<b>6. TRABAJOS FUTUROS .....</b>	<b>46</b>
<b>7. BIBLIOGRAFÍA .....</b>	<b>47</b>

## Índice de figuras

Figura 1. Ejemplo ilustrativo de un diagrama de flujo .....	12
Figura 2. Modelo del espacio de color RGB .....	14
Figura 3. Modelo de espacio de color CIELAB .....	16
Figura 4. Analogía entre el espacio de color RGB y HSV .....	17
Figura 5. Modelo de espacio de color HSV .....	18
Figura 6. Modelo de espacio de color HSV con coloración .....	18
Figura 7. Horizonte 1 con sus 4 diferentes capas .....	24
Figura 8. Horizonte 2 con sus 4 diferentes capas .....	24
Figura 9. Horizonte 3 con sus 4 diferentes capas .....	24
Figura 10. Tabla de colores de las diferentes capas que conforman un perfil de la Guía Rasta.....	25
Figura 11. Cambio de variable de entero a doble precisión .....	27
Figura 12. Base de datos suministrada por los descriptores .....	27
Figura 13. Diagrama de flujo del descriptor RGB .....	30
Figura 14. Diagrama de flujo del descriptor HSV, CIELAB y HSV con transformada de Fourier. ....	31
Figura 15. Distribución de los datos para un modelo entrenado en el plano cartesiano .....	32
Figura 16. Distribución de los datos para un modelo lineal entrenado con descriptor RGB en el perfil 1 ..	33
Figura 17. Distribución de los datos para un modelo lineal entrenado con descriptor HSV en el perfil 1 .	34
Figura 18. Distribución de los datos para un modelo lineal entrenado con descriptor CIELAB en el perfil 1 .....	34
Figura 19. Matriz de confusión para los datos de validación .....	35
Figura 20. Distribución de datos de entrenamiento para un modelo lineal basado en máquinas de soporte vectorial con descriptor RGB en el perfil 2.....	36
Figura 21. Distribución de datos de entrenamiento para un modelo lineal basado en máquinas de soporte vectorial con descriptor HSV en el perfil 2 .....	37
Figura 22. Distribución de datos de entrenamiento para un modelo lineal basado en máquinas de soporte vectorial con descriptor CIELAB en el perfil 2. ....	37
Figura 23. Matriz de confusión de entrenamiento para un modelo basado en redes neuronales con descriptor RGB en el perfil 2. ....	38
Figura 24. Matriz de confusión de entrenamiento para un modelo basado en redes neuronales con descriptor HSV en el perfil 2. ....	38

Figura 25. Matriz de confusión de entrenamiento para un modelo basado en redes neuronales con descriptor CIELAB en el perfil 2.....41

Figura 26. Matriz de confusión de validación..... 41

Figura 27. Matriz de confusión de validación..... 41

Figura 28. Distribución normal de frecuencia no acumulada de medias aritméticas en las 4 clases del canal 1 de los descriptores RGB y CIELAB..... 42

Figura 29. Distribución normal de frecuencia no acumulada de medias aritméticas en las 4 clases del canal 2 de los descriptores RGB y CIELAB..... 42

Figura 30. Distribución normal de frecuencia no acumulada de medias aritméticas en las 4 clases del canal 3 de los descriptores RGB y CIELAB..... 42

## Índice de tablas

Tabla 1. Matriz de confusión.....	22
-----------------------------------	----

## Agradecimiento

En primera instancia quiero agradecerle a la UNIVERSIDAD TECNOLÓGICA DE PEREIRA por haberme aceptado ser parte de ella y abrirme las puertas para estudiar la carrera que tanto me motiva, así como también le agradezco a mis diferentes formadores, aquellas personas de gran sabiduría, quienes de una u otra manera se esfuerzan cada día por ayudar a sus estudiantes a llegar hasta este punto en el que me encuentro, no puedo decir que el proceso ha sido sencillo, pero las ganas, la dedicación y aquellos conocimientos brindados que me han regido, he logrado importantes objetivos como el de culminar mi carrera con éxito y obtener una afable titulación profesional.

Agradezco también a mi director de Tesis el Ingeniero Electrónico Arley Bejarano Martínez M.Sc. por haberme brindado la oportunidad de recurrir a sus capacidades y conocimientos, así como también haberme tenido toda la paciencia para guiarme durante el desarrollo de la tesis.

## **1. INTRODUCCIÓN**

La presente investigación se enfoca en el problema que afronta gran parte de los podólogos, edafólogos y algunos agricultores colombianos de pequeñas, medianas y grandes extensiones de tierras en la identificación de las capas que conforman el subsuelo, sea para cultivar, estudiar su estado natural o hacer un estudio referente a sus posibles usos. Esta propuesta ofrece técnicas de visión por computador con métodos cuantitativos y objetivos que pueden identificar de manera certera y concisa, todas aquellas cualidades físicas que conforman la tierra, dejando atrás aquellos métodos subjetivos y pocos convencionales basados en los sentidos humanos. Así como también dejar enmarcada una alternativa diferente a los grandes costos que conlleva un análisis de suelos por parte de laboratorios y agrónomos.

Las técnicas de visión por computador son una opción entre una gran variedad de tecnologías y metodologías, que permiten medir y cuantificar información necesaria para la toma de decisiones en cuanto al estado actual del suelo a analizar, haciendo uso de una gran variedad de procesos como filtros digitales, segmentación de imágenes y espacios de color como herramientas útiles en la identificación de colores presentes en dichas capas (“subsuelo”).

Muchas son las ventajas de utilizar visión por computadora, siendo la entrega de resultados, la más eficiente superando por mucho la estipulada por laboratorios, así como también la opción de replicar cuantas veces sea requerido los datos sin coste adicional. Del mismo modo la portabilidad de equipos e instrumentos necesarios para la toma de muestras es mucho más asequible pues solo consta de una cámara digital o en muchos casos de teléfonos celulares.

## 1.1 PLANTEAMIENTO DEL PROBLEMA

Colombia por estar ubicada en la esquina noroccidente de América del Sur, goza de diferentes particularidades geográficas que facilitan y dan origen a múltiples regiones y hábitats naturales propicios para todo tipo de cultivos, siendo estas siembras indispensables para el desarrollo económico del país [1]. Juan José Perfetti, economista agrícola de la Universidad Nacional-sede Medellín cita en el libro, Políticas para el desarrollo de la agricultura en Colombia, la importancia de que el agricultor conozca las características físico-químicas del suelo, ya que el crecimiento, el desarrollo, la cantidad y calidad de las cosechas están en relación directa con los nutrimentos y las características de los suelos [2].

Sin embargo, la determinación de tierras requiere de técnicas de alto nivel cognitivo y científico en el cual el método más utilizado hasta la época es el análisis de suelos, hecho por un podólogo, presentando dificultades a nivel de tiempo y costo monetario. Por otro lado, el Centro Internacional de Agricultura Tropical (CIAT) conjunto a la Corporación Biotec y La Universidad Nacional de Colombia han desarrollado una metodología para caracterizar el suelo y el terreno de una forma simple y en el sitio, que los agricultores podrán usar para conocer sus recursos y tomar las mejores decisiones para el manejo de los mismos[3], la cual es llamada guía RASTA, no obstante la guía presenta dificultades a la hora de obtener datos verídicos, certeros y replicables por cada usuario que aplican la metodología de la guía al mismo suelo a analizar, dado que se obtiene información diferente dependiendo de la capacidad visual del individuo, ocasionando la necesidad de implementar procedimientos de visión por computador estructurados en los procesos descriptivos de caracterización de suelos entregados por la guía RASTA, eliminando la subjetividad en la medida realizada.

Por lo tanto, el problema de investigación se basa en analizar técnicas de visión por computador y de aprendizaje de maquina con el fin de determinar cuál presenta mejores resultados a la hora de analizar los subsuelos. Haciendo uso de espacios de color y análisis estadísticos en la búsqueda de las mejores características de matiz y saturación de cada perfil de tierra siendo fácilmente reconocibles, implementadas en el entorno de desarrollo integrado (IDE) de matlab®.



## 1.2 JUSTIFICACIÓN

Uno de los mayores problemas que enfrenta la guía de caracterización de suelos y terrenos de una forma simple y en el sitio, llamada “Guía Rasta”, es la incapacidad de reproducibilidad de equivalentes resultados para el mismo perfil de tierra analizado, bajo idénticas condiciones climáticas, esto es debido a que el instrumento analizador se encuentra bajo influencia directa de la subjetividad del observador, por ende se hace necesario formular un análisis comparativo de técnicas de visión por computadora para la clasificación de subsuelos de manera análoga como plantea la “Guía Rasta”.

Esto con la finalidad de mutar a mejores metodologías en la identificación de nuestro entorno agrícola multivariado, cuya gran parte se comporta de forma errática e impredecible, imposibilitando la implementación de tecnologías extranjeras adaptadas a climas y entornos diferentes, siendo en su mayoría estacionarias o estables, así como también promover iniciativas técnicas y tecnológicas en la construcción de un campo más eficiente, rentable y naturalmente armonioso[2][10], a partir de la experiencia de los miles de campesinos a los cuales está dirigida la tecnología, pues no hay mejor experto en el tema la hora de labrar la tierra que las mismas manos que la siembran; Y ya que la repercusión directa en la investigación de métodos técnicos y tecnológicos que faciliten la labor del campesinado se ve reflejada en su calidad de vida que adquieren los mismos[10], lo convierten en un tema de investigación por excelencia.

### 1.3 OBJETIVO GENERAL

Realizar un análisis comparativo de técnicas de visión por computador para la clasificación de subsuelos de *Pereira-Risaralda*.

### 1.4 OBJETIVOS ESPECÍFICOS

- Crear una base de datos anotada con tres diferentes perfiles de suelos.
- Implementar descriptores de color y de textura que permitan la extracción de características de los diferentes perfiles de suelos.
- Implementar los algoritmos de máquina de soporte vectorial y redes neuronales los cuales permitirán realizar la clasificación de los subsuelos.
- Realizar un análisis estadístico combinando los diferentes descriptores y los diferentes métodos de aprendizaje de máquina y reportar los resultados.

## 1.5 ESTADO DEL ARTE

Algunos referentes actuales atribuidos a desarrollos de visión por computador, implica la identificación de malezas en sembradíos de cereales en su etapa de crecimiento, en donde la realización del estudio es necesario el análisis de imágenes procedentes de campos y centros agrícolas, con la peculiaridad, de que las imágenes están constituidas por diferentes elementos estructurales físicos que sean diferenciables de las malezas , ya que las plantas en sus estados tempranos presentan diferentes tonalidades de verdes siendo irreconocibles unas de otras a simple vista, un aspecto en particular en el análisis es la alineación en forma de surcos en que se siembran las plantas o dispersas según se trate de cultivo; de esta manera, la investigación se centra en el análisis de las texturas existentes en las imágenes captadas por los sistemas de visión en campos, lo cual se realiza desde los puntos de vista: cromático y espacial. [4].

La importancia de supervisar de manera eficiente los campos en los cuales se produzca agricultura de precisión se hace necesario la implementación de drones civiles para la elaboración de orto mosaicos, en conjunto con imágenes satelitales para la identificación de las condiciones geológica óptimas para los diferentes cultivos y aprovechar al máximo condiciones del terreno en el que se piensa sembrar, [5] la implementación de algoritmos de reconocimiento y orientación de robots móviles sobre la base de patrones de color para el escalonamiento exacto de la posición es otro estudio realizado por los ingenieros V. Antipov, V. Kokovkina, V. Kirnos and A. Priorov, el cual consiste en un robot que juega futbol a través del reconocimiento del color, La instalación robosoccer llamado así por sus desarrolladores comprende la plataforma robótica móvil con una mesa para la fijación del patrón de color que consiste en círculos de color rojo, verde y azul, un marco vertical especial para la fijación de la cámara digital y la computadora personal con la visión por computadora y los algoritmos de toma de decisiones. [6], la construcción de mapas de terreno locales precisos para vehículos autónomos de visión y LiDAR, es otro referente actual de métodos de visión por computadora, ya que la construcción de un mundo plano, para la percepción del entorno por parte de robots móviles hacia la navegación de forma autónoma ya no es válido, por tal razón para dar realismo al hábitat que se enfrentan los vehículos autónomos se elaboran mapas precisos del terreno por espacio -fusión temporal, por medio de datos de múltiples sensores complementarios que no solo consiste en las probabilidades de obstáculos, sino que contiene

diferentes características del entorno tales como elevación, color, reflectividad infrarroja, pendientes del terreno y rugosidad superficial [7], el diseño de sistema de visión por computador para detectar frutas y verduras con defectos durante el transporte y almacenamiento a través de histogramas de color es un proyecto que destaca al máximo las técnicas de visión por computadora, puesto que al utilizar histogramas de color en diferentes parches de imágenes de frutas y verduras procesadas para su posterior análisis se crean las condiciones óptimas para el desarrollo de un SVM lineal (máquina de vector de soporte) proporcionando un modelo de selección con la robustez necesaria para evitar que alimentos con bajos índices de calidad lleguen al consumidor [8], y a nivel nacional, tenemos el Protocolo de Procesamiento Digital de Imágenes para la Cuantificación de la Deforestación en Colombia a través de sensores ópticos de baja y media resolución espacial implementada por el Ministerio de Medio Ambiente y Vivienda, esto con el fin de tener un monitoreo de extensión, de la cobertura de áreas boscosas a nivel global, nacional, regional y local, que constantemente se ven afectadas por bandas dedicadas a la explotación ilegal de recursos naturales [9].

## 2. MARCO TEÓRICO

### 2.1 Base de datos

La base de datos es un conjunto de información específica, de manera que todos los grupos relevantes estén representados en los datos, estos relacionaran cualquier tema desde investigación, operación o identificación, ya sean nombres de usuarios de una empresa de prestación de servicios o números de carros que utilizan gas en lugar de gasolina en los municipios de un departamento ciudad o región en específico [11].

### 2.2 Algoritmo

Es un conjunto prescrito de instrucciones o reglas bien definidas, ordenadas y finitas que permite realizar una actividad mediante pasos sucesivos que no generen dudas a quien deba realizar dicha actividad. Ver figura 1.

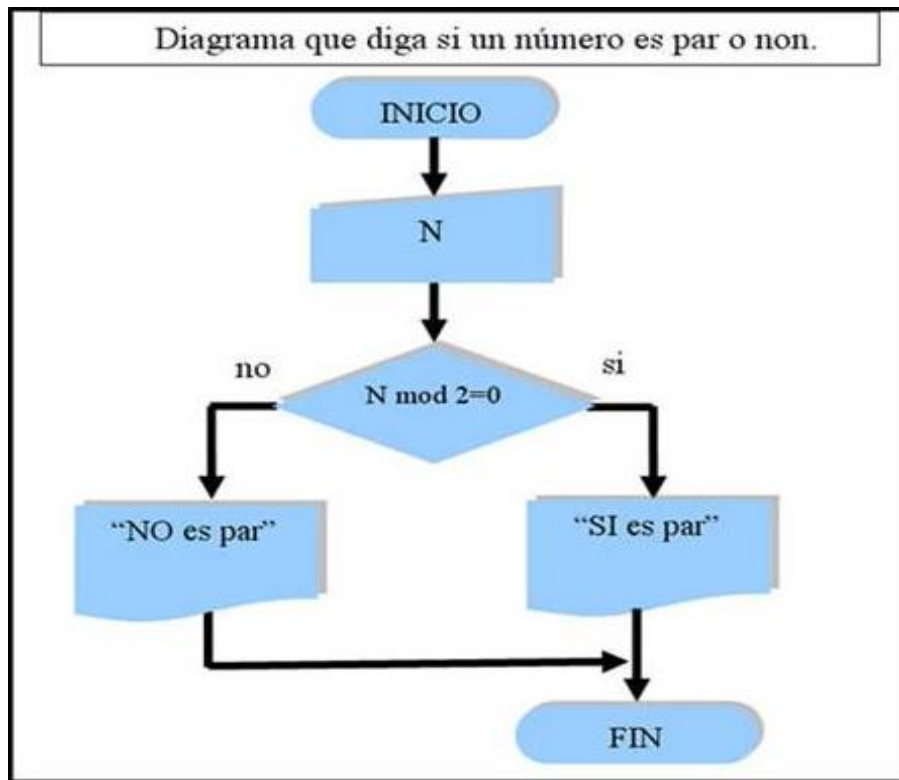


Figura 1. Ejemplo ilustrativo de un diagrama de flujo

## 2.3 Espacios de color

Un espacio de color se puede representar de manera simple como un plano cartesiano , donde cada punto orientado en este representa una componente numérica de un color en específico de características reproducibles; Un espacio de color esta formulado por un modelo matemático en su mayoría de forma abstracta donde describe la forma en que los colores pueden orientarse y dependiendo del medio por la que viaja la información del color y la tecnología en donde se pretenda utilizarse se crean diferentes espacios de color donde los más utilizados a nivel comercial son RGB, HSV, CIELAB, CMY[12][14].

## 2.4 Modelo de color RGB

Es el espacio de color más ampliamente utilizado, en su mayoría en transmisiones de señales analógicas o representaciones digitales; Basado en el modelo triestímulo y síntesis aditiva, consta de la combinación de los colores primarios, luz , azul , rojo y verde siendo este último referencia a la teoría del color del mundo digital y no de su análogo amarillo del mundo real, es un modelo arduamente competitivo y poderoso pues una sola imagen en espacio RGB, en la combinación de sus tres colores puede crear en pantalla hasta 16.7millones de colores diferentes.

normalmente para que los ojos humanos puedan diferenciar colores entre si, se hace necesario tres cualidades intrínsecas de estos, brillo, tono y saturación; El brillo es la iluminación relativa del color, donde 0% es negro y 100% es blanco, el tono es el color reflejado a través de los objetos, es como percibimos los colores que normalmente identificados por nombres, azul, amarillo, rojo y la saturación es la cantidad de tono de un color en específico combinada con luz blanca, lo que nos indica la pureza del color.

En el espacio RGB los colores rojo, verde, azul son representados por cantidades numéricas positivas, que van desde [0-255] siendo cero la ausencia del color y 255 su máxima representación, la combinación de los tres colores en un plano de tres dimensiones donde cada plano conforma una estela de color, da como resultado en dispositivos multimedia y procesamiento digital de imágenes una variedad finita de colores, en donde sus valores mínimos da como resultado la representación del color negro y en su mayor nivel el blanco, como se puede ver en la figura 2. [12][13][14].




Figura 2. Modelo del espacio de color RGB

### Leyes de Grassman

Estas leyes conceptualizan en una serie de conclusiones de la teoría de “la mezcla adictiva del color”, que se conocen actualmente como las “leyes de Grassman” en honor al físico alemán que las sistematizó hace 165 años.

Primera ley: *“ley de la trivariancia visual”*

De acuerdo a la composición adictiva del color, se pueden conseguir todos los colores que percibimos, mezclando tan solo tres franjas de la gama visible o notoria, como los colores: rojo, verde y azul, pero manejando unas proporciones adecuadas, con la condición de que la unión de dos de los tres colores no sea del mismo color del sobrante. Al buscar un nuevo color se maneja la siguiente formula, siendo la C, R, G y B estímulos monocromáticos y  $\alpha$ ,  $\beta$  y  $\gamma$  las cantidades de luz de cada estímulo cromático.

$$C = \alpha(R) + \beta(G) + \gamma(B)$$

Segunda ley: “ley de la luminancia”

De acuerdo a esta ley, se indica que un color puede ser el resultante de la unión de dos radiaciones cromáticas o dos colores primarios: verde, rojo y azul, con la condición de que si la unión de dos colores de los tres no puede ser igual al tercer color.

$$C_3 = C_1 + C_2 \quad \text{Si} \quad (R_1 + R_2)(R) + (G_1 + G_2)(G) + (B_1 + B_2)(B)$$

Tercera ley: “ley de la proporcionalidad”

Siempre que dos superficies produzcan igual sensación cromática es posible variar su luminancia, manteniendo constante el matiz y la saturación, sin que varíe la igualdad cromática entre ambas superficies.

$$\text{Si } C_1 = C_2 \quad \text{entonces} \quad kC_1 = kC_2$$

Cuarta ley: “ley de la aditividad”

Puesto que cualquier color resultante de la unión de los colores primarios: verde, rojo y azul, y que a su vez también se están sumando sus respectivas luminancias, por ende la luminancia de un color x es igual a la suma de las luminancias de sus colores primarios que lo componen.

$$Lum(C) = Lum(R) + Lum(G) + Lum(B)$$

## 2.5 Modelo de color CIE L\*A\*B\*

CIELAB es un espacio de color estandarizado por CIE (comisión internacional de la iluminación) en 1976, y su característica más relevante es la obtención de la uniformidad de su espacio de color en el cual es posible tomar las características de tono, brillo y saturación de un color en un punto determinado del espacio orquestado, y así mismo la diferencia que tiene este con cualquier otro



situado en el mismo con relación de su distancia entre por medio. Esto quiere decir que los colores se representan en el espacio a una distancia proporcional a las diferencias visuales entre ellos.

Los tres parámetros que representan el modelo son la luminosidad  $L^*$ , la posición entre rojo y verde  $a^*$  donde los valores negativos de  $a$  indican tonalidades verdes, los positivos rojos, la posición entre amarillo y azul  $b^*$  donde los valores negativos de  $b$  indican tonalidades azules, los positivos amarillos. Ver figura 3. [12][13][21]




Figura 3. Modelo de espacio de color CIELAB

La transformación del modelo RGB al espacio CIELAB mediante los valores  $L^*$ ,  $a^*$  y  $b^*$ , se calculan mediante transformaciones no lineales, haciendo uso del espacio XYZ:

$$L^* = \begin{cases} 116 \left( \frac{Y}{Y_n} \right)^{1/3} - 16 & \text{si } \frac{Y}{Y_n} > 0.008856 \\ 903.3 \left( \frac{Y}{Y_n} \right) & \text{si } \frac{Y}{Y_n} \leq 0.008856 \end{cases}$$

$$a^* = 500 \left[ \left( \frac{X}{X_n} \right)^{1/3} - \left( \frac{Y}{Y_n} \right)^{1/3} \right]$$

$$b^* = 200 \left[ \left( \frac{Y}{Y_n} \right)^{1/3} - \left( \frac{Z}{Z_n} \right)^{1/3} \right]$$

## 2.6 Modelo de color HSV

Los parámetros de este color se denominan tono (H), saturación (S) y valor (V) este espacio de color tiene su origen en el cubo del espacio RGB el cual al observar la diagonal que se presenta en el espacio RGB en el vértice negro P(0,0,0) al blanco P(255,255,255) se visualiza claramente un hexágono[12][21]. Ver figura 4.




Figura 4. Analogía entre el espacio de color RGB y HSV

En el espacio HSV su saturación se mide con respecto al eje horizontal y su valor con el eje vertical pasando por el centro del cono hexagonal, el tono se representa mediante ángulos con respecto al eje vertical donde cada grado representa un color y cada vértice del hexágono está separado por 60 grados. Ver figura 5 y 6. [12][21].





Figura 5. Modelo de espacio de color HSV



Cono de colores del espacio HSV.

Figura 6. Modelo de espacio de color HSV con coloración

## 2.7 Transformada de Fourier

El matemático Joseph Fourier demostró que toda función periódica puede ser expresada como una suma infinita de senos y cosenos de diferentes frecuencias, donde el análisis de una señal continua, permite determinar sus frecuencias acosta de perder alguna información de tipo temporal. En aplicaciones con imágenes, la transformada rápida de Fourier (FFT) permite pasar cualquier señal discreta, en este caso, una imagen al dominio de la frecuencia, permitiendo tratar una cantidad de filtros dependiendo de la composición armónica de la imagen para una mejor extracción de propiedades.

## 2.8 Máquina de soporte vectorial

Una máquina de soporte vectorial en su idea más básica, esta vista como una caja negra la cual cuenta con tres entradas y una sola salida; Donde dos de sus tres entradas son para entrenamiento y una sola para validación, además de argumentos numéricos de salida como resultado final, que no siempre se encuentra habilitado al igual que la entrada de validación.

La máquina de soporte vectorial, "la caja negra" recibe una dupla de datos por sus dos entradas de entrenamiento, este par de datos, consiste en una etiqueta y en un valor numérico que describe una cualidad, propiedad o característica del sistema o sistemas analizados; Sin embargo, por este par de entradas también pueden llegar una gran variedad de etiquetas con su respectivo valor, de uno o más sistemas, siendo la combinación de pares de etiquetas y valores numéricos clases, en el cual la cantidad de clases depende de la cantidad de etiquetas en sí.

Una vez adentro, los datos se organizan por clases tratando de mantener la distancia entre sí, lo más que se pueda, esto se hace a través de vectores de soporte en la búsqueda de un hyperplano que los separe, y ayude a la clasificación del dato que entra por la puerta de validación, a saber a cuál de las múltiples clases pertenece; saliendo así la etiqueta de la clase a la cual el dato pertenece o ha sido clasificado según las características del sistema suministrado.

De forma más formal, una máquina de soporte vectorial está determinada por un grupo de entrenamiento de tamaño  $N$  compuesto de pares atributo-etiqueta  $(x_i, y_i) 1 \leq i \leq N$ , siendo  $x_i \in \mathbb{R}^n$  y  $y_i \in \{-1, 1\}$ , de este se obtiene una ecuación para un hyperplano que deriva de dicho grupo

de entrenamiento, de manera que aquellos puntos con igual etiqueta queden al mismo lado del hiperplano. Una solución a esta situación es mapear el espacio de entrada, en un espacio de características de una dimensión mayor y buscar el hiperplano óptimo allí. Sea  $z = \varphi(x)$  la notación del correspondiente vector en el espacio de características con un mapeo  $\varphi$  de  $\mathcal{R}^N$  a un espacio de características  $\mathcal{Z}$ . Esto significa encontrar un  $w$  y un  $b$  tal que:

$$y_i(\omega' x_i + b) > 0, i = 1, \dots, N$$

Esto sería para el caso linealmente separable, pero para cualquiera de los casos no linealmente separables se utilizan diferentes kernels derivados de los multiplicadores de Lagrange, alguno de estos casos son: polinomial, función de base radial, sigmoide. [15][22]

Para el caso lineal, suponiendo que se tienen  $N$  observaciones  $(x_i, y_i)$   $1 \leq i \leq N$  para  $x_i \in \mathbb{R}^n$  y  $y_i \in \{-1, 1\}$  donde  $y_i$  es la etiqueta para  $x_i$ , se asume que existe una probabilidad  $P(x, y)$  para la cual los datos están descritos. Sea dada una máquina, cuya tarea es aprender a mapear  $x_i \rightarrow y_i$ , dicha máquina es ciertamente definida como un grupo de posibles mapeos  $x \rightarrow f(x, \alpha)$  donde las funciones  $f(x, \alpha)$  son descritas por los parámetros ajustables  $\alpha$ . Una elección particular de  $\alpha$ , genera una “máquina entrenada” en particular. Esto es, por ejemplo, una red neuronal con una arquitectura fija, donde  $\alpha$  corresponde a los pesos y los desplazamientos, es en efecto una máquina de aprendizaje. [15][23][24]

## 2.9 Estadística

“La estadística estudia métodos científicos para recoger, organizar, resumir y analizar datos, así como para sacar conclusiones válidas y tomar decisiones razonables basadas en tal análisis” [Murray R. Spiegel].

La Media aritmética es el valor promedio de las muestras y es independiente de las amplitudes de los intervalos. Se simboliza como  $\bar{X}$  con una barra horizontal sobre el símbolo y se encuentra sólo para variables cuantitativas. Se encuentra sumando todos los valores y dividiendo por el número total de datos. [11][18].

La desviación estándar es una medida de dispersión, que nos indica cuánto pueden alejarse los valores respecto al promedio (media), por lo tanto es útil para buscar probabilidades de que un evento ocurra. [11][19]

El sesgo es un error que aparece en los resultados de un estudio debido a factores que dependen de la recogida, análisis, interpretación, publicación o revisión de los datos que pueden conducir a conclusiones que son sistemáticamente diferentes de la verdad o incorrectas acerca de los objetivos de una investigación. Este error puede ser sistemático o no. [11].

La curtosis es una medida estadística, que determina el grado de concentración que presentan los valores de una variable alrededor de la zona central de la distribución de frecuencias, donde dependiendo el grado de curtosis se presentan tres tipos de distribuciones Leptocurtica, Mesocurtica y Platicurtica. [11][20].

## 2.10 Matriz de confusión

La matriz de confusión tiene su origen, en la implementación de modelos de clasificación, los cuales son capaces de predecir a qué clase va a pertenecer una nueva solicitud de entrada, basándose en lo aprendido en instancias anteriores. Por tal motivo una vez modelado un método de clasificación aceptable surge la necesidad de evaluar los resultados de la predicción, con criterio en los siguientes cuestionamientos. ¿Qué porcentaje de la datos clasifica correctamente?, ¿qué porcentaje de la datos clasifica incorrectamente?, exactitud, tasa error, sensibilidad exhaustividad, precisión [17][16].

La matriz de confusión para un problema de  $n$  clases es una matriz  $n \times n$ , en la que las filas se nombran según las clases reales y las columnas, según las clases previstas por el modelo. Para un modelo binario, la matriz se forma como se muestra en la tabla 1.

		PREDICCIÓN	
		Positivos	Negativos
OBSERVACIÓN	Positivos	Verdaderos Positivos (VP)	Falsos Negativos (FN)
	Negativos	Falsos Positivos (FP)	Verdaderos Negativos (VN)

Tabla 1. Matriz de confusión

VP: Es la cantidad de positivos que fueron clasificados correctamente como positivos por el modelo.  
 VN: Es la cantidad de negativos que fueron clasificados correctamente como negativos por el modelo.

FN: Es la cantidad de positivos que fueron clasificados incorrectamente como negativos.

FP: Es la cantidad de negativos que fueron clasificados incorrectamente como positivos.

#### Exactitud:

$$Exactitud = \frac{VP + VN}{Total}$$

#### Tasa de error:

$$Tasa\ de\ error = \frac{FP + FN}{Total}$$

#### Sensibilidad, Exhaustividad, Tasa de verdaderos positivos:

$$Sensibilidad = \frac{VP}{Total\ Positivos}$$

### 3. METODOLOGÍA

La finalidad de este proyecto es realizar un análisis comparativo de técnicas de visión por computadora para el análisis de subsuelos en la región de Pereira Risaralda, con el objetivo de identificar los descriptores de color, textura o la combinación de ambos que presentan mayores cualidades en la abstracción de componentes de color, brillo, tono y saturación de cada perfil de tierra suministrado.

Inicialmente se requiere la obtención o la construcción de una base de datos que permita poner a prueba descriptores de color y textura, a través de técnicas ópticas de visión por computadora de tres diferentes perfiles de tierra, los cuales serán separados por su respectivo color.

Haciendo un breve paréntesis, se puede dar a conocer que en la medida que se desarrollaron las labores de campo en la obtención de la base de datos requerida, se encontró que ningún ente público o privado en el área agrícola de la región Risaraldense, que fue visitado hasta el momento por el estudiante en su labor investigativa, siendo esto tres semanas y media después de la radicación del proyecto, cuenta entre sus archivos con algún tipo de base de datos parecida o similar que faciliten su labor, por lo cual, en ese instante se opta por la construcción del mismo.

El primer paso en la construcción de la base de datos solicitada, es encontrar algún terreno o campo, el cual no haya sido manipulado de ninguna manera previa, asegurando que en el momento de la extracción de la tierra para la toma de muestras, el perfil sea fácilmente apreciable y con ello sus diferentes capas, la “Guía Rasta” recomienda hacer una cajuela en el suelo de 60 cm de ancha por 60 cm de larga por 170 cm de profundidad, esto si son cultivos perennes como árboles frutales, si no es así, será por 60 cm de profundidad[2], una vez realizadas las cajuelas en diferentes puntos del terreno, se dispondrá de una cámara digital para la toma de muestras a tres perfiles de tierra necesarios.

En el terreno disponible para la caracterización de suelos, se implementó una cantidad de 15 cajuelas diseminadas en diferentes puntos, y se tomaron muestras de los tres perfiles más claramente



diferenciables, donde estos a su vez, presentaron cuatro capas finamente reconocibles, tomando la cantidad de 600 fotos a cada capa de perfil, en diferentes ángulos, con diferentes sombras en el transcurso de dos horas, esto con el objetivo de agregar ruido y diferencias notables entre cada una de las fotos, ejerciendo más presión en los descriptores que más adelante se desarrollarán y diferencias significativas que hagan más fácil la clasificación en el mediante uso de máquinas de soporte vectorial y redes neuronales, así como también en simular un ambiente hostil climatológicamente hablando al cual se puede enfrentar un campesino a la hora de tomar las fotos. Como ejercicio práctico se implementara un piloto el cual hace exactamente lo contrario, es decir, se tomaran 600 fotos en las cuales se harán en un solo Angulo, con la mínima sombra y todas de una vez con la misma intensidad de luz para análisis comparativo, estas imágenes fueron implementadas al perfil número uno. En las figuras 7, 8 y 9 se muestran las fotos correspondientes:

#### Perfil 1



Figura 7. Horizonte 1 con sus 4 diferentes capas

#### Perfil 2



Figura 8. Horizonte 2 con sus 4 diferentes capas

#### Perfil 3



Figura 9. Horizonte 3 con sus 4 diferentes capas

Es importante apuntar que la “Guía Rasta” denota en su tabla de colores 54 variedades de capas que pueden conformar un perfil de tierra, y en un ambiente más científico su variedad puede alcanzar los 50 mil colores, donde cada una de ellas presenta características diferentes, como también denotar que una hectárea de tierra puede estar compuesta únicamente por un perfil como de varios. En este contexto, la labor de encontrar todos los diferentes colores que forman un horizonte en una sola extensión de tierra, se convierte en improbable y en una tarea muy ardua de gran capital técnico y humano, por tal motivo, los tres perfiles de tierra seleccionados para pruebas fueron los perfiles que más se repitieron en el transcurso de muchas excavaciones y salidas de campo, para ello se aprovechó la gran inversión constructora que tiene el área metropolitana de Pereira en los diferentes municipios que lo conforman, en estas constructoras suelen retirar la capa vegetal del suelo y exponer el primer metro cincuenta de tierra facilitando el trabajo de excavación, llegando en algunos casos a la toma de imágenes requerida, como se muestra en la figura 10.




Figura 10. Tabla de colores de las diferentes capas que conforman un perfil de la Guía Rasta

En la medida que el trabajo investigativo va mostrando sus primeros resultados, la idea del ente investigador es ampliar la base de datos, con fines de hacer una tipificación del suelo completa y fiable.

Una vez adquirida la base de datos necesaria para el desarrollo de los siguientes objetivos específicos, se continuará con la ejecución de descriptores de color y textura, que permitan la extracción de características de los diferentes horizontes, para ello se utiliza el sistema PC Notebook HP 15-h007, el cual es un computador portátil con características de gama media fácilmente encontrable en el mercado local, diseñado para ambientes empresariales y familiares, con características técnicas como es el procesador acelerado AMD E1-2100 de 1,0 GHz, este mismo cuenta con una memoria cache de 1 MB de nivel 2, una memoria SDRAM DDR3L de 4 GB (1 DIMM) y una unidad de almacenamiento interno de 500 GB, cualidades necesarias para el óptimo funcionamiento de los algoritmos a construir.

En el computador portátil se procede a crear una carpeta en el disco local C con el nombre de “base de datos”, en la cual se dispondrán las imágenes digitales en formato “jpg”, donde esta a su vez, se dividirá en cuatro subcarpetas correspondientes a cada capa de color obtenidas del horizonte de tierra, conteniendo 600 imágenes para un total de 2400 por perfil, esto con la finalidad de ubicar el folder que requiere Matlab en sus operaciones.

Dentro del entorno de desarrollo de Matlab, se crea un script con el nombre de RGB2.m, en el cual se implementarán los descriptores de color. Estos consisten en exportar el folder “base de datos” a Matlab, donde utilizando la estructura iterativa “for”, se cargarán las 2400 imágenes distribuidas en las cuatro subcarpetas de la carpeta central “base de datos”, teniendo en cuenta la carpeta madre a que pertenecen. A cada imagen seleccionada se pasarán sus tres canales RGB de valores enteros [0, 255] a una matriz de las mismas características, pero de variables de doble precisión a través de la función `im2double`, ver figura 11; esto con el objetivo de aplicar cambios a la estructura de los canales o aplicar la matriz componente en diferentes procesos y no perder información en el proceso, una vez obtenido los tres canales en doble precisión, estos se separarán y aplicarán procesos estadísticos de tendencia y dispersión en la búsqueda de información relevante o de interés sobre cada canal, donde con esto se puede evaluar datos de mayor interés como el tono más dominante, que tanto se distribuyen la gama de colores sobre la tendencia central, cuáles son sus frecuencias y de qué forma se distribuyen. Esto se logra empleando la media aritmética, la desviación estándar, el sesgo y la curtosis descritas en el ítem anterior.

	1	2	3	4	5		1	2	3	4	5
1	101	96	91	87	86	1	0.3412	0.4118	0.5608	0.5647	0.5569
2	104	98	91	87	87	2	0.3412	0.3843	0.5412	0.5608	0.5412
3	105	100	94	89	89	3	0.3255	0.3922	0.5216	0.5725	0.5804
4	100	98	95	93	92	4	0.3216	0.4275	0.5451	0.5804	0.5686
5	92	93	95	96	95	5	0.3373	0.4157	0.5725	0.5804	0.5216
6	86	89	93	95	94	6	0.3373	0.4118	0.5843	0.5686	0.5490
7	85	88	91	92	90	7	0.3922	0.4824	0.5569	0.5529	0.5608
8	84	86	89	89	87	8	0.4196	0.5608	0.5647	0.5608	0.5765
9	95	94	92	90	88	9	0.4745	0.5725	0.5412	0.5294	0.5529
10	98	96	93	89	87	10	0.5333	0.5765	0.5490	0.5216	0.5529

Figura 11. Cambio de variable de entero a doble precisión

Como ya se mencionó, el algoritmo que precisa al descriptor de color toma cada una de las fotos y las separa en sus tres canales, así que agarra cada canal en su forma matricial con sus valores de doble precisión y le aplica la media, la desviación, el sesgo y la curtosis; ajuntando estos nuevos datos, uno al lado del otro en una nueva matriz denominada “datos”, ver figura 12, esta nueva matriz tiene por dimensiones un numero de 2400 filas correspondiente a las 2400 imágenes y 13 columnas, de las cuales sus primeros 4 columnas corresponde al canal rojo, las columnas 5 al 8 del canal verde y de las columnas 9 al 12 del canal azul, sin embargo, este cuenta con una columna más y es de tipo etiquetas, pues cada imagen corresponde a una carpeta, así que a cada carpeta se le asigna un valor numérico empezando desde el 1 hasta el número de carpetas que haya, a su vez heredando esta cualidad a cada imagen.

	2	3	4	5	6	7	8	9	10	11	12	13
1	0.0186	5.0431	-0.3991	0.4826	0.0155	5.2625	-0.1451	0.3387	0.0121	5.0775	0.2534	1
2	0.0180	4.5714	-0.2082	0.4853	0.0156	4.1721	-0.1063	0.3394	0.0123	5.3827	0.1244	1
3	0.0216	4.7868	-0.4679	0.4875	0.0156	3.9822	-0.2409	0.3450	0.0112	5.9993	0.3172	1
4	0.0216	4.7868	-0.4679	0.4875	0.0156	3.9822	-0.2409	0.3450	0.0112	5.9993	0.3172	1
601	0.0249	4.2859	0.9232	0.5097	0.0184	4.5100	0.6273	0.3856	0.0160	10.9276	1.2163	2
602	0.0249	4.2859	0.9232	0.5097	0.0184	4.5100	0.6273	0.3856	0.0160	10.9276	1.2163	2
603	0.0123	29.3329	-0.4711	0.4890	0.0134	17.2824	0.1932	0.4333	0.0138	17.2086	1.2961	2
604	0.0123	29.3329	-0.4711	0.4890	0.0134	17.2824	0.1932	0.4333	0.0138	17.2086	1.2961	2
1201	0.0108	3.4312	-0.1339	0.5171	0.0127	4.9820	-0.0927	0.5110	0.0136	5.0159	0.0033	3
1202	0.0108	3.4312	-0.1339	0.5171	0.0127	4.9820	-0.0927	0.5110	0.0136	5.0159	0.0033	3
1203	0.0132	9.4733	0.4224	0.4825	0.0119	11.4115	0.5888	0.4775	0.0101	10.2682	0.5434	3
1204	0.0132	9.4733	0.4224	0.4825	0.0119	11.4115	0.5888	0.4775	0.0101	10.2682	0.5434	3
1801	0.0137	4.0213	0.1198	0.5151	0.0141	3.7217	0.1912	0.5117	0.0138	2.9476	0.3931	4
1802	0.0137	4.0213	0.1198	0.5151	0.0141	3.7217	0.1912	0.5117	0.0138	2.9476	0.3931	4
1803	0.0246	5.9298	0.7761	0.5066	0.0257	6.7419	0.6226	0.5073	0.0251	7.1823	0.5913	4
1804	0.0246	5.9298	0.7761	0.5066	0.0257	6.7419	0.6226	0.5073	0.0251	7.1823	0.5913	4

Figura 12. Base de datos suministrada por los descriptores

De esta manera queda conformado el primer descriptor, los otros dos descriptores de color se establecen cambiando el espacio de color de cada una de las imágenes y para el caso del descriptor de color con textura se usa como base cualquiera de los descriptores de color ya implementados y adicionarle una nueva columna, siendo la número 14, donde se efectúa la transformada rápida de Fourier para señales discretas a cada una de las imágenes, proporcionando nueva información que permita una clasificación más eficiente a través de las componentes de frecuencias de cada una de estas, los nuevos espacios son HSV y CIELAB; para la transformación de espacios solo es necesario implementar los comandos `rgb2hsv` y `rgb2lab` de Matlab. Este paso de transformación se implementa una vez que nuestro programa pasa nuestras imágenes de variables `unit8` a `double`, ya que con cualquier espacio de color es necesario manejar una resolución más amplia, así como una mayor capacidad de memoria, teniendo la imagen ya lista, el procedimiento se repite, sólo que en estos casos no son canales RGB sino que son los canales propios de cada espacio de color, así como una nueva matriz de datos con sus características, los diagramas de flujo para cada los descriptores son los que se pueden observar en las figuras 13 y 14.

Con los descriptores de color debidamente desarrollados, el siguiente paso es la construcción de una máquina de soporte vectorial y red neuronal, el cual de una manera exacta se entrenarán 3 máquinas de soporte vectorial con 3 redes neuronales por cada descriptor. Para poder entrenar cada una de estas, es necesario que los datos propios de cada descriptos se separen en dos, un 70% de entrenamiento y un 30% de validación, estos son 1680 datos de entrenamiento y 720 de validación, en el caso de una red neuronal se utiliza 70% para entrenamiento 15% de validación y un 15% de testeo, una vez exportada la carpeta que contiene los identificadores a Matlab, con la función `randperm` se generan 2400 números aleatorios, de los cuales se escogen 1680, y se organizan en un vector columna llamado “entre” y los 720 restantes de la misma manera se organizan en un vector columna de nombre “valida”, el siguiente paso es extraer del archivo “datos” con característica propia de cada descriptor exportado a Matlab, los valores correspondientes en el vector “entre” y “valida” , y asignarlos a dos nuevas matrices y su correspondiente pareja vector columna de etiquetas llamadas **A**, **Y** y **AP**, **YP**. La matriz **A** recibirá el 70% de información de “datos” y **Y** todas aquellas etiquetas de las clases a las que pertenece cada información, a su vez **AP** recibirá el 30% de información de “datos” y **YP** todas aquellas etiquetas restantes. Con estos datos es posible generar un Mdl en Matlab con la función `fitcecoc` pasando como parámetros **A** y **Y**, datos y etiquetas. La

función `predic` nos permite validar el restante 30% de la base de datos “datos” el cual nos dirá a qué clase pertenece nuestros datos, para asegurarnos que los datos suministrados si corresponden a las etiquetas a los cuales fueron asignados por `predic` se hace su comprobación a través de la matriz de confusión. En el caso de una red neuronal este proceso se implementa con el `neural pattern recognition` Matlab esto es un toolbox , el cual se encargar de implementar todo de forma automática, una vez dentro de la app solo es necesario extraer la base de datos y por si solo se encarga de separar los datos ya sea para entrenamiento, validación o testeo y al final te entrega los datos incluyendo la matriz de confusión.

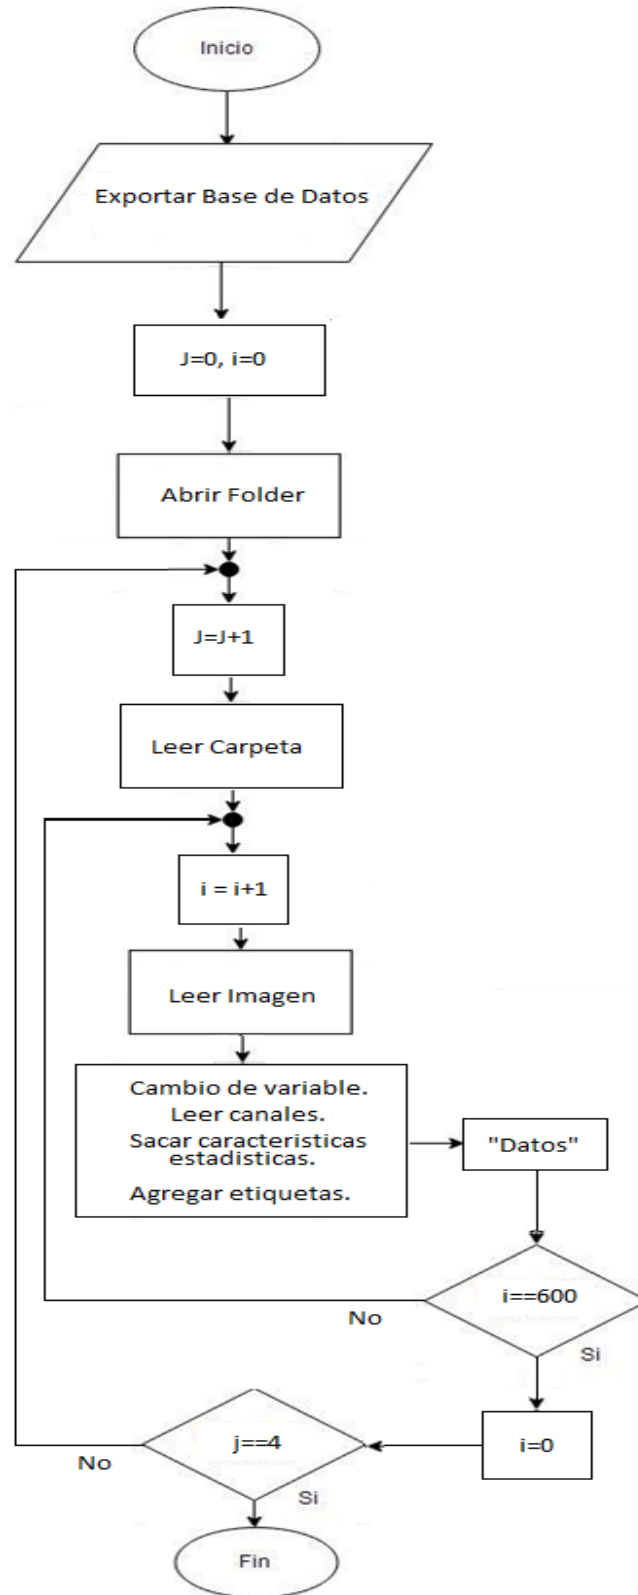


Figura 13. Diagrama de flujo del descriptor RGB



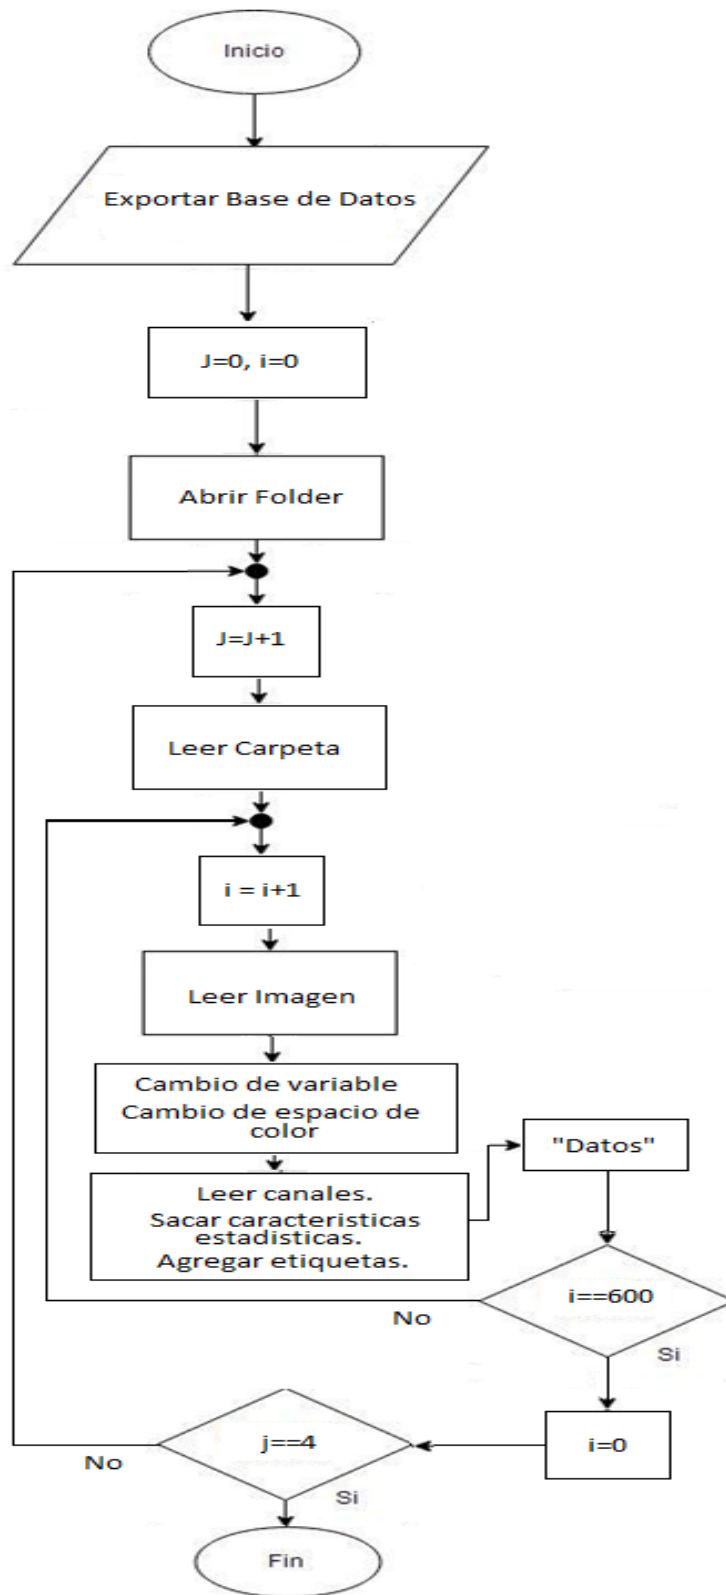


Figura 14. Diagrama de flujo del descriptor HSV, CIELAB y HSV con transformada de Fourier



#### 4. ANÁLISIS Y RESULTADOS

- Se encontró que para los datos provenientes del perfil 1 o perfil piloto, las características entre la misma capa de perfil son iguales unas de otras, esto es debido a que no se le ingresa ruido a las imágenes, por lo tanto, más de 600 datos organizados en el “*classification learner*” se encuentran en un mínimo de 1 punto y un máximo de 5, en concentraciones de 80 datos o 600, en la misma coordenada del plano cartesiano. Ver figura 15.




Figura 15. Distribución de los datos para un modelo entrenado en el plano cartesiano

- A raíz de que los datos no presentan patrones complejos en su distribución, para un clasificador implementado por medio de máquinas de soporte vectorial y redes neuronales, no se le es complicado alcanzar un 100% de exactitud en el entrenamiento de la matriz, siendo este resultado una réplica idéntica en cada uno de los descriptores implementados hasta el momento: RGB, HSV, CIELAB. Las siguientes imágenes muestran una comparación de cada una de las maquinas entrenadas con un kernel lineal de cuatro clases, donde cada clase es representada por un color, siendo la clase uno identifica por el color azul, la clase dos por el color naranja, la clase tres por el color amarillo y la clase cuatro por el color violeta. En estas figuras el eje coordenado **X**, representa la columna 1 de cualquier base de datos suministrada por un descriptor, donde esta columna almacena todas las medias aritméticas del primer canal de cada espacio de color, sea este R, H ó L y en el eje coordenado **Y** tenemos a la columna 5, que representa la media aritmética del segundo canal de cada espacio de color sea G, S, ó A para una imagen. Ver figura 16, 17 y 18.




Figura 16. Distribución de los datos para un modelo lineal entrenado con descriptor RGB en el perfil 1




Figura 17. Distribución de los datos para un modelo lineal entrenado con descriptor HSV en el perfil 1




Figura 18. Distribución de los datos para un modelo lineal entrenado con descriptor CIELAB en el perfil 1

- Las consecuencias de tomar información de un perfil en condiciones estáticas, tal y como se muestra en los datos arrojados por el perfil 1, son desfavorables en la validación del modelo entrenado, por tal razón para poder ejemplificar las consecuencias de esto, se decide crear una nueva base de datos con el descriptor CIELAB y las imágenes del perfil 2. La forma en que se crea esta nueva base se realiza a través de la extracción de una única imagen de cada capa que crea el horizonte duplicándose hasta conformar las 2400 imágenes requeridas para entrenar un nuevo modelo de características planas, tal y como se evidencia en la figura 15. A este nuevo modelo entrenado se le ingresan como datos de validación, información del descriptor CIELAB del perfil 2 anterior a esta base de datos, el cual contiene una aleatoriedad en sus imágenes. Ver figura 19.

A.		C =			
	132	26	8	2	
	72	112	0	0	
	52	73	62	0	
	11	102	11	57	

B.		C =			
	169	0	0	0	
	0	188	0	0	
	0	0	173	0	
	0	0	0	190	

Figura 19. Matriz de confusión para los datos de validación. (A) Para un modelo con características planas y datos de validación fluctuantes. (B) Para un modelo con características fluctuantes y datos de validación planas

En la figura 19, parte A, observamos la matriz de confusión de los datos de validación, donde los resultados son concluyentes, ya que para un modelo entrenado con una sola imagen por capa de tierra, al ser validado con datos reales muestran una distribución en toda la matriz de confusión, llegando a obtener en algunos casos más falsos negativos y falsos positivos que datos acertados (verdaderos positivos y verdaderos negativos), siendo para este caso su exactitud del 50.41%; esto se debe a que una máquina de soporte vectorial forma un hyperplano de la mayor distancia posible y con datos de entrenamiento tan

sesgados, ocasiona la incertidumbre de posición.

De forma inversa, en la figura 19, parte B, tenemos la matriz de confusión para los datos de validación de un modelo entrenado con base a los datos del verdadero perfil dos, con el descriptor CIELAB y proporcionando datos de validación de características planas, es decir, la falsa base de datos, teniendo como resultado una exactitud del 100% como se puede apreciar.

- Para los perfiles 2 y 3 se presentaron características completamente diferentes, en estos dos horizontes las diferentes capas que los conforman, tienen una distribución más dispersa dentro del plano cartesiano, esto se debe a que a estos dos últimos perfiles se les incrementa el ruido notoriamente, como ya se ha mencionado, las diferentes sombras en la toma de imágenes, la intensidad lumínica y diferentes ángulos, provoca patrones característicos en cada una de ellas como se muestran en la figuras 20, 21 y 22.




Figura 20. Distribución de datos de entrenamiento para un modelo lineal basado en máquinas de soporte vectorial. (A) Descriptor RGB en el perfil 2. (B) Exactitud del modelo entrenado y tiempo de entrenamiento en segundos.




Figura 21. Distribución de datos de entrenamiento para un modelo lineal basado en máquinas de soporte vectorial. (A) Descriptor HSV en el perfil 2. (B) Exactitud del modelo entrenado y tiempo de entrenamiento en segundos.




Figura 22. Distribución de datos de entrenamiento para un modelo lineal basado en máquinas de soporte vectorial. (A) Descriptor CIELAB en el perfil 2. (B) Exactitud del modelo entrenado y tiempo de entrenamiento en segundos.

Los resultados para los mismos dos horizontes en la clasificación a través de redes neuronales, se muestran a través de matrices de confusión. Ver figura 23, 24 y 25.




Figura 23. Matriz de confusión de entrenamiento para un modelo basado en redes neuronales. (A) Descriptor RGB en el perfil 2. (B) Tiempo de entrenamiento en segundos.

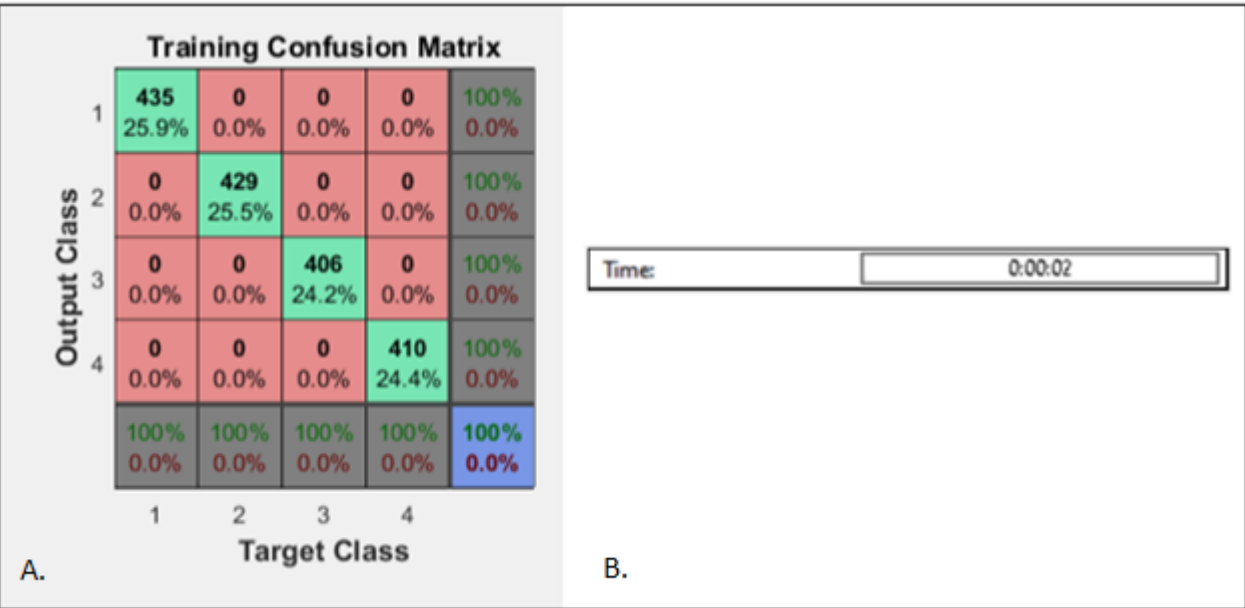


Figura 24. Matriz de confusión de entrenamiento para un modelo basado en redes neuronales. (A) Descriptor HSV en el perfil 2. (B) Tiempo de entrenamiento en segundos.




Figura 25. Matriz de confusión de entrenamiento para un modelo basado en redes neuronales. (A) Descriptor CIELAB en el perfil 2. (B) Tiempo de entrenamiento en segundos.

Aunque la exactitud en los tres descriptores utilizados presenta buenos rendimientos, esto no es del todo cierto, ya que en cada uno de los descriptores presenta precisiones diferentes en los dos métodos clasificadores. Es importante aclarar que cada espacio de color es creado con un objetivo específico y que la disposición de sus componentes espectrales afecta significativamente cada imagen, destacando cualidades como anulando otras; para este caso en concreto, tenemos una exactitud del 100% para los descriptores en HSV y CIELAB y con un 98.5% para el descriptor RGB, siendo estos, clasificadores de soporte vectorial, y para redes neuronales claramente se aprecia un 100% de exactitud en el entrenamiento de la matriz en descriptores HSV y CIELAB, y para el descriptor RGB un 99.34%.

La matriz de confusión no solamente nos da a saber en qué exactitud queda el modelo entrenado o con qué exactitud fueron clasificados los datos de validación de dicho modelo, sino que también ofrece información de otras propiedades importantes tales como: la tasa de error, sensibilidad, especificidad, precisión y valor de predicción negativo, y como sustentación se obtiene dichos parámetros a los modelos entrenados con descriptores basados en el espacio de color RGB en ambos métodos de clasificación, ya que para descriptores HSV y CIELAB donde su exactitud es del 100% no se le encuentra sentido



alguno siendo estos los resultados, para un descriptor RGB basado en máquinas de soporte vectorial la tasa de error se encuentra en 1.9%, para la clase 4 una sensibilidad del 97% y una precisión del 95% , para un descriptor RGB basado en redes neuronales la tasa de error se encuentra en 0.65%, para la clase 3 una sensibilidad del 97.4% y una precisión del 100%.

- Una comparación que se hace necesaria entre cada método de clasificación, resulta de la comprobación del tiempo en el que cada clasificador construye un modelo con los diferentes descriptores, donde el mejor tiempo de entrenamiento lo obtuvo el modelo basado en redes neuronales con el descriptor CIELAB, siendo un segundo de construcción; y el de mayor tiempo con 7.8 segundos basado en el descriptor RGB con una estructura de soporte vectorial. De forma concreta, los modelos realizados a través de redes neuronales tienen mejor desempeño que los implementados con máquinas de soporte vectorial, siendo los tiempos de 3, 2 y 1 segundos para los descriptores RGB, HSV y CIELAB en redes neuronales y 7.8, 5.8 y 3.2 para los descriptores RGB, HSV y CIELAB en máquinas de soporte vectorial. Ver figuras 20, 21, 22, 23, 24 y 25 Parte (B).
- Con las matrices de confusión una vez que se tiene entrenado el modelo, se aprecia con qué exactitud se clasifican los datos en las pruebas de validación, este proceso se hace reiterativo, excepto en el caso, donde tenemos un modelo en el que su matriz de confusión para los datos de validación, da como resultado un 100% después de un determinado número de pruebas, y se da por sentado que ese es su valor absoluto, no obstante, para modelos donde su exactitud varía entre prueba y prueba, se es necesario implementar el experimento de Montecarlo para determinar en qué porcentaje de exactitud se estabiliza el modelo. Este procedimiento Montecarlo sólo fue aplicado en los descriptores RGB y HSV de clasificación por medio de máquinas de soporte vectorial, como también al descriptor RGB de clasificación de redes neuronales, siendo los resultados: 80.69% para RGB, 92.91% para HSV y 98.61% para RGB respectivamente. Ver figura 26 y 27.

156	18	0	0
6	173	0	0
0	3	126	52
0	0	60	126

A.

184	0	0	0
2	174	0	0
0	0	153	15
0	0	34	158

B.

182	0	0	0
0	191	0	0
0	0	172	0
0	0	0	175

C.

Figura 26. Matriz de confusión de validación. (A) Para un modelo de soporte vectorial y descriptor RGB. (B) Para un modelo de soporte vectorial y descriptor HSV. (C) Para un modelo de soporte vectorial y descriptor CIELAB




Figura 27. Matriz de confusión de validación. (A) Para un modelo de redes neuronales y descriptor RGB. (B) Para un modelo de redes neuronales y descriptor HSV. (C) Para un modelo de redes neuronales y descriptor CIELAB

- Para ayudar a comprender por qué el descriptor con espacio de color CIELAB presenta notables mejoras ante un espacio RGB, se analizó las bases de datos suministrada por cada descriptor del perfil 2, en el cual fue aplicado una distribución normal a cada columna que tenga como parámetro, las medias aritméticas de los 3 canales, juntando las 4 capas de horizonte en un mismo gráfico, siendo este el resultado. Ver figuras 28, 29 y 30.




Figura 28. Distribución normal de frecuencia no acumulada de medias aritméticas en las 4 clases del canal 1 de los descriptores RGB y CIELAB




Figura 29. Distribución normal de frecuencia no acumulada de medias aritméticas en las 4 clases del canal 2 de los descriptores RGB y CIELAB

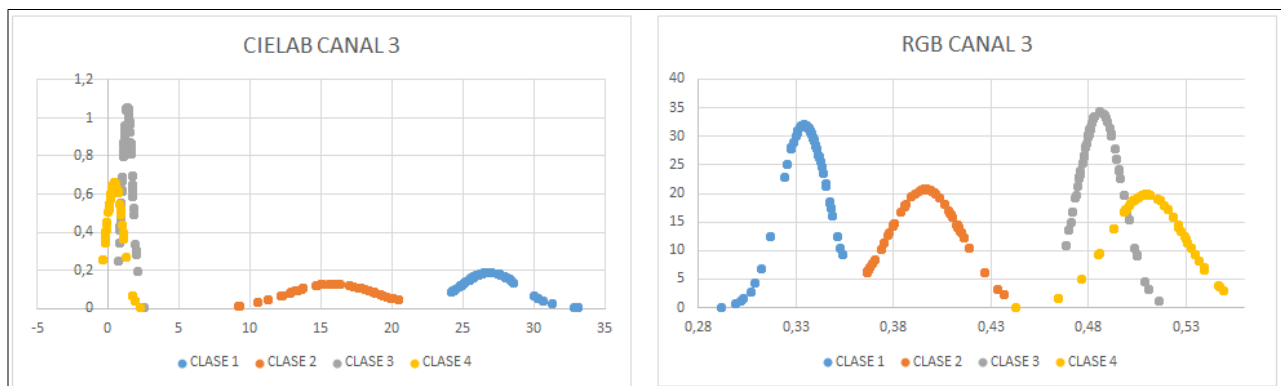


Figura 30. Distribución normal de frecuencia no acumulada de medias aritméticas en las 4 clases del canal 3 de los descriptores RGB y CIELAB

Como se evidencia a simple vista, para un descriptor RGB, la distribución normal de los tres canales en la combinación de las 4 capas tierra que lo conforman, se presenta mayor traslape de campanas de gauss, mayoritariamente entre las clases 3 y 4 del perfil 2, siendo estas de considerable similitud respecto al color, ocasionando mayor error en la clasificación en los datos de entrada referentes a estas etiquetas; ya que como metodología a seguir por los algoritmos de clasificación, es la eliminación de los parámetros de entrenamiento que hacen inseparable las clases, para este caso en concreto, las gráficas correspondientes a las medias aritméticas del canal 1 del descriptor CIELAB y canal 2 del descriptor RGB, quedando como parámetros el resto de los canales, notándose más fuerte el traslape en el descriptor RGB con relación a CIELAB

## CONCLUSIONES

- Se afirma la versatilidad y la capacidad de los descriptores utilizados para la clasificación de subsuelos, estos proveen herramientas y datos necesarios con la robustez requerida para la tipificación de sub suelos en la medida que las capas analizadas sean homogéneas y claramente diferenciables, sin importar el cambio cromático que presenten, donde este cambio cromático en la mayoría de los casos, no son perceptibles por los ojos humanos, es importante aclarar que no existe claramente, una capa de horizonte literalmente homogénea en el sentido del color, como se podría encontrar en una pantalla de televisión; con homogeneidad se refiere referencia a un color de tierra que puede tener dos o varios tonos de colores distribuidos con cierta aleatoriedad dentro de su composición, que vista de una forma simple parece presentar un sólo tono al cual se le pueden extraer datos.
- Se concluye que a la hora de extraer información del perfil de tierra, es importante que las imágenes posean cierto grado de distribución, representando todo tipo de climas, intensidades lumínicas y ambientes naturales a los que se pueden enfrentar un campesino o un ente investigador al tomar las fotos, con el fin de evitar la incertidumbre en la clasificación de las diferentes capas que conforman un horizonte.
- Aunque todos los descriptores de color tuvieron un buen desempeño, en la medida que se amplíe la base de datos y las unidades cromáticas entre cada capa que conforma un horizonte se acerquen más. Se hace evidente que las características de conformación de cada espacio de color, juega un papel más dominante, esto se puede observar en las medidas estadísticas de media aritmética y curtosis que presentan los diferentes espacios. Así pues en la medida que los colores presenten más similitudes entre sí, esta margen tiende a acortarse, tendiendo a la posibilidad de utilizar métodos no lineales de clasificación.
- Los tiempos en el cual, cada método clasificador gesta los modelos no es concluyente, esto en la medida de proporcionar información, que permita diferenciar uno del otro y entender en qué casos es más eficiente utilizar redes neuronales o máquinas de soporte vectorial a la hora de clasificar, sin embargo, es bien sabido que las redes neuronales tienen el menor tiempo de

gestación de modelos, pero a su vez es el clasificador que requiere de mayor recursos del sistema; y aunque nuestro modelo de clasificación posee cuatro clases, el cual no es ningún problema para el equipo computacional, el número de clases pueden extenderse a más de 200 requiriendo mayor gasto operacional del sistema, y aquí es donde se concluye si la prioridad es velocidad a precio computacional, o menor nivel operativo a mayor tiempo.

- El espacio de caracterización, que de forma más completa puede identificar diferentes trazos de color, es el descriptor implementado con el espacio de color CIELAB, ya con este descriptor una vez realizadas todas las pruebas mostro mejores desempeños en comparación con el resto de descriptores, muestra de ello es la distribución normal que presentan las medias aritméticas en los canales  $A^*$ ,  $B^*$  en comparación de los canales R, G, B del espacio RGB. Ver figuras 28, 29 y 30. Ya que dejando aparte el canal  $L^*$  de este espacio de color, el cual representa la iluminación, los canales  $A^*$ ,  $B^*$  poseen un distribución uniforme del color y claramente diferenciables entre ellos, aun para colores de pequeñas variaciones cromáticas como es el caso de las capas 3 y 4 del perfil dos. Ver figura 9.

- El mejor método de clasificación, se dio por parte de las redes neuronales, este método mostro mayor ventaja a los métodos de separación por máquinas de soporte vectorial en cada uno de los descriptores, tanto en el tiempo de entrenamiento como en la exactitud en el modelo entrenado. Ver figuras 23, 24 y 25 parte (A y B). cada uno de los modelos entrenados por redes neuronales fue dispuesto por 12 capas, ya que a mayor número de capas mayor tiempo en consolidar un modelo y mayor recursos computacionales requiere pero a su vez mayor eficiencia, sensibilidad y menor tasa de error.

## **6. TRABAJOS FUTUROS**

- Con base a lo desarrollado, futuras investigaciones pueden tener como base estos planteamientos, uno de estos es la articulación de características que presentan los diferentes subsuelos, en el estado de sus nutrientes con el correspondiente color que presentan.
- El diseño de un aplicativo móvil que pueda hacer la misma labor realizada por el ente investigativo desde una plataforma android y un lenguaje de programación de java.
- Se puede implementar en este proceso de recolección de muestras fotográficas, otras características del terreno a cosechar, como lo es la pendiente que está relacionada con la retención del agua, su posible erosión, así como la respectiva maquinaria a utilizarse; la forma del terreno los cuales pueden ser plano o llano, ondulado, montañoso y ondulado-montañoso, la posición del perfil, los cuales pueden ser: meseta, cima, ladera convexa, ladera cóncava, ladera plana, plano, plano con ondulaciones y pie de elevación; todas estas características se pueden clasificar con los mismos métodos vistos.
- A través de técnicas de visión por computadora y métodos de clasificación por máquinas de soporte vectorial y redes neuronales, se pueden generar modelos capaces de detectar diferentes enfermedades en cultivos a los que se le realicen estudios por medio de captura de imágenes generando así un sistema donde la imagen a analizar pueda detectar que tipo de enfermedad, bacteria, hongo o plaga está afectando y a su vez, que arroje una descripción sobre ella y como contrarrestarla.

## 7. BIBLIOGRAFÍA

- [1] "El clima, los pisos térmicos y la agricultura en Colombia", *Las Plantas y el Campo*, 2012. .
- [2]J. Perfetti and A. Becerra, *Políticas para el desarrollo*, 1st ed.
- [3] Cock, James H.RASTA Rapid Soil and Terrain Assessment: Guía práctica para la caracterización del suelo y del terreno / James H. Cock, Diana M. Alvarez, Marcela Estrada. Versión 2. Cali, CO : Centro Internacional de Agricultura Tropical (CIAT); Corporación BIOTEC, 2010.
- [4] M. Riomoros Callejo, "Segmentación automática de texturas en imágenes agrícolas", TESIS DOCTORAL, UNIVERSIDAD COMPLUTENSE DE MADRID, FACULTAD DE INFORMÁTICA,Departamento de Ingeniería del Software e Inteligencia Artificial, 2016.
- [5]D. Marcovecchio and J. Ferrari, *Ortomosaicos utilizando Imágenes Aéreas tomadas por Drones y su aplicación en la Agricultura de Precisión*, 2014.
- [6] V. Antipov, V. Kokovkina, V. Kirnos and A. Priorov, "Computer vision system for recognition and detection of color patterns in real-time task of robot control", 2017 Systems of Signal Synchronization, Generating and Processing in Telecommunications (SINKHROINFO), 2017.
- [7] H. Jaspers, M. Himmelsbach and H. Wuensche, "Multi-modal local terrain maps from vision and LiDAR", 2017 IEEE Intelligent Vehicles Symposium (IV), 2017.
- [8] L. Wang, X. Tian, A. Li and H. Li, "Machine Vision Applications in Agricultural Food Logistics", 2013 Sixth International Conference on Business Intelligence and Financial Engineering, 2013.
- [9] Cabrera, E., G. Galindo & D.M. Vargas. 2011. Protocolo de Procesamiento Digital de Imágenes



para la Cuantificación de la Deforestación en Colombia, Nivel Nacional Escala Gruesa y Fina. Instituto de Hidrología, Meteorología, y Estudios Ambientales IDEAM-. Bogotá D.C., Colombia. 44 p.

[10] Asistencia Técnica Internacional del Tercer Laboratorio de Paz, "CAMPEÑINOS, TIERRA Y DESARROLLO RURAL", Bogotá, 2011.

[11] Levin, Richard I., and David S. Rubin. *Estadística para administración y economía*. México: Pearson Educación, 2004.

[12] F. Ortiz Zamora, *Procesamiento morfológico de imágenes en color*. [Alicante]: Fundación Biblioteca Virtual Miguel de Cervantes, 2002.

[13] J. Artigas, P. Capilla Perea and J. Pujol i Ramo, *Tecnología del color*. Valencia: Universitat de València, 2002.

[14] *Bibing.us.es*, 2018. [Online]. Available: <http://bibing.us.es/proyectos/abreproy/11875/fichero/Proyecto+Fin+de+Carrera%252F3.Espacios+de+color.pdf>.

[15] R. Henao, "Selección de Hiperparámetros en Máquinas de Soporte Vectorial", M.Sc., UNIVERSIDAD NACIONAL DE COLOMBIA, 2004.

[16] M. confusión and P. Recuero, "Machine Learning a tu alcance: La matriz de confusión", *Data-speaks.luca-d3.com*, 2018. [Online]. Available: <http://data-speaks.luca-d3.com/2018/01/ML-a-tu-alcance-matriz-confusion.html>.

[17] "RPubs - Matriz de Confusión - Evaluación de modelos de predicción", *Rpubs.com*, 2018. [Online]. Available: <https://rpubs.com/chzelada/275494>

[18] S. Maths, "Media aritmética - Probabilidad y estadística", *Sangakoo.com*, 2018. [Online]. Available: <https://www.sangakoo.com/es/temas/media-aritmetica>.

[19]"QUÉESLADESVIACIÓNESTÁNDARYCOMOINTERPRETARLA#1", *TradingCenter*, 2018.[Online].Available:<https://tradingcenter.wordpress.com/2009/11/11/que-es-la-desviacion-estandar-y-como-interpretarla-1/>.

[20]U. Formulas, "Curtosis", *Universo Formulas*, 2018. [Online]. Available: <http://www.universoformulas.com/estadistica/descriptiva/curtosis/>.

[21] D. Hearn and M. Baker, *Gráficos por computadora con OpenGL*. Madrid [etc.]: Pearson Addison Wesley, 2011.

[22] BETANCOURT, G. (2018). LAS MÁQUINAS DE SOPORTE VECTORIAL (SVMs). [online]Revistas.utp.edu.co.Availableat:<http://revistas.utp.edu.co/index.php/revistaciencia/article/view/6895/4139> [Accessed 23 May 2018].

[23]C. Burges. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, vol. 2, no. 2, 1998.

[24] C. Burges B. Schölkopf and A. Smola. *Advances in kernel methods: Support vector machines*. Cambridge, MA: MIT Press, 1999.